Soft computing

K.N. Toosi University of Technology

محاسبات نرم

Hasan Ghasemzadeh

http://wp.kntu.ac.ir/ghasemzadeh

Soft Computing

Neural Networks شبکه عصبی

مغز انسان

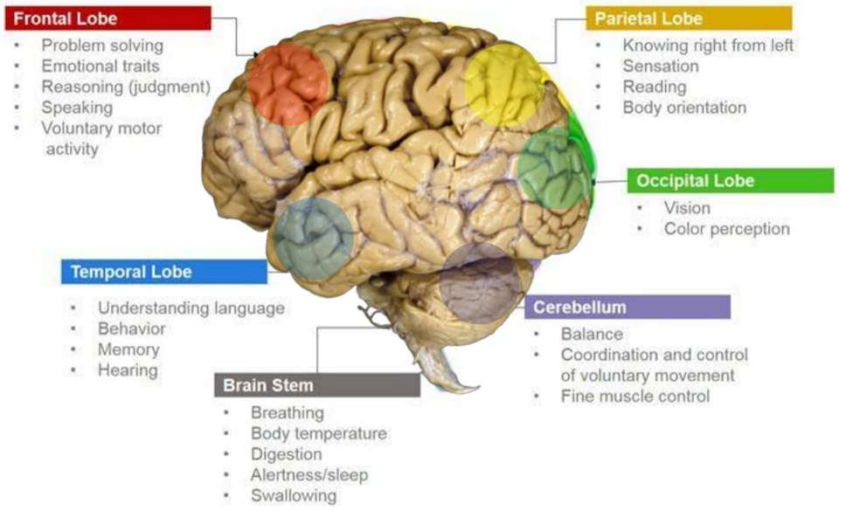

Soft Computing 3

برخی ویژگیهای مغز

- یک توده بافت عصبی(مغز انسان – حدود ۱/۴ کیلوگرم و ۱/۵ لیتر)
- هدایت کل جسم بصورت خودآگاه و ناخودآگاه
- مرکز اندوختن تجربه، یادگیری و تصمیم گیری
- حجم حافظه بالا و سرعت پردازش زیاد
- نامشخص بودن نحوه عملکرد مغز(تاکنون)

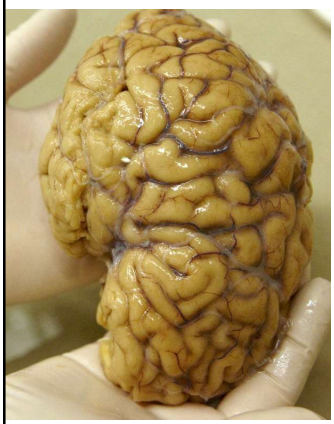

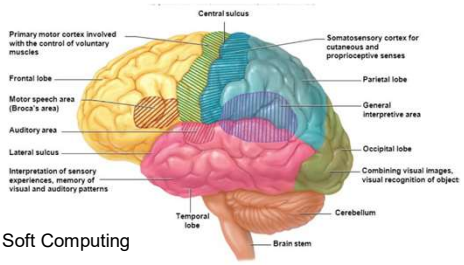

Soft Computing 4

برخی ویژگیهای مغز

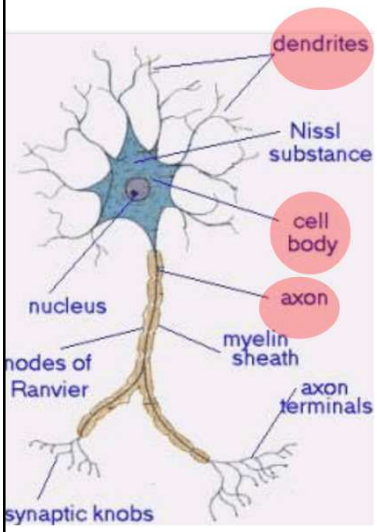

- مغز شامل ۸۶ میلیارد نورون (۱۹ درصد در قشر حدود ۳ میلیمتری مغز و ۸۰ درصد در مخچه)
- نورون‌ها از یک جسم سلولی، دندریت و آکسون تشکیل شده‌اند.
- نورون اطلاعات را از طریق سیگنال‌های الکتریکی و شیمیایی منتقل می‌کند.
- نورون‌ها انرژی خود را از طریق یک شکاف کوچک به نام سیناپس(بیش از ۱۰۰ تریلیون سیناپس) به یکدیگر منتقل می‌کنند

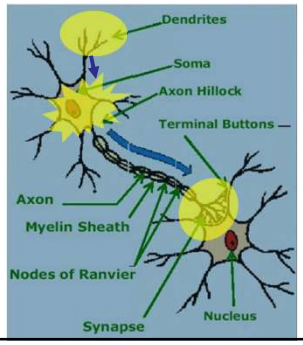

The soma, sums the incoming signals. When sufficient input is received, the cell fires; that is it transmit a signal over its axon to other cells

5

برخی ویژگیهای مغز

The “one learning algorithm” hypothesis

گرچه هر قسمت مغز وظیفه مخصوص خود را انجام می دهد ولی در شرایط خاص محرومیت از برخی سنسورها سعی بر جابجایی وظایف خود میکند

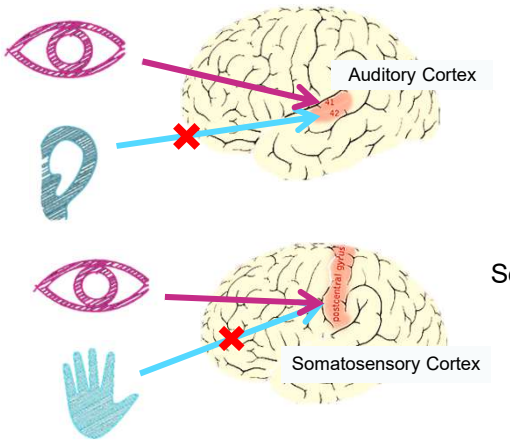

Auditory cortex learns to see

[Roe et al., 1992]

Somatosensory cortex learns to see

[Metin & Frost, 1989]

Soft Computing 6

مقایسه مغز انسان و رایانه

Feature	Human (Brain)	Computer
Processing Elements	~86 billion neurons	100 billion in modern chips (like Apple M2).
Interconnects	~10,000 synaptic connections per neuron	a few interconnects per transistor.
Cycles per Second	~200 Hz to 1000 Hz (neuron firing rate)	Up to 5 GHz
Memory	Dynamic and associative (estimated ~2.5 PB)	Explicit, structured (up to terabytes).
2X Improvement	Evolved over millions of years	~1.5–2 years

Neuron

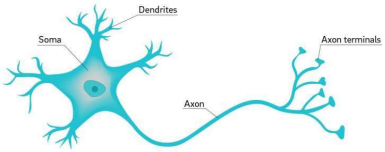

بلوک کلی یک دروازهٔ منطقی

پرسپترون

- شبکه عصبی مصنوعی از رفتار نورنهای مغز تقلید می کند.
- یک واحد منطقی مدلی از یک نورن است.
- شبکه‌های تک لایه، با توابع فعال سازی آستانه‌ای، توسط روزنبلات (۱۹۶۲) بنیان‌گذاری شدند که این نوع شبکه‌ها، پرسپترون نامیده شدند.

Neuron model: Logistic unit

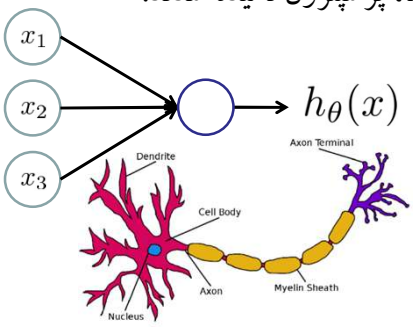

$$x = \begin{Bmatrix} x_0 \\ x_1 \\ x_2 \\ x_n \end{Bmatrix} \quad w = \begin{Bmatrix} w_0 \\ w_1 \\ w_2 \\ w_n \end{Bmatrix}$$

Sigmoid (logistic) activation function

مدل ریاضی یک نرون (مک کلاخ–پیتس–۱۹۴۳)

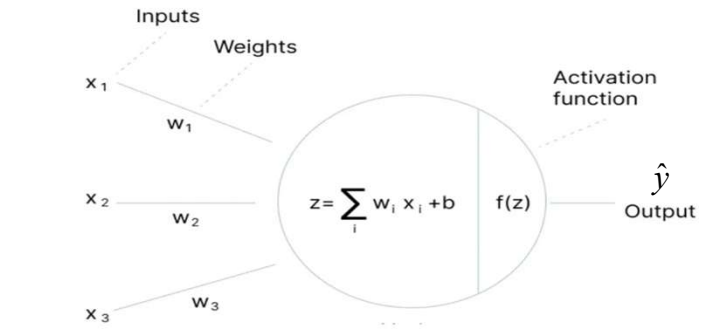

۹

Soft Computing

پرسپترون

- From biological neuron to artificial neuron (perceptron)

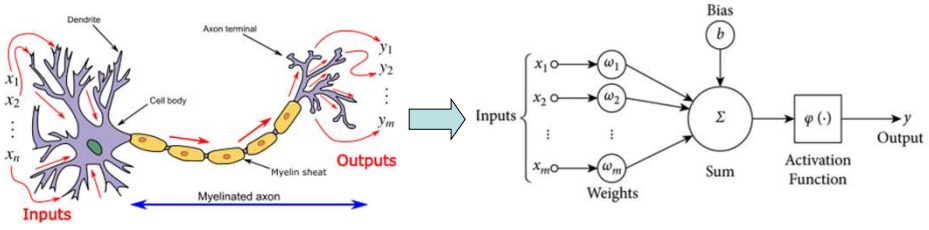

$$z = w_0 x_0 + w_1 x_1 + w_2 x_2 + \ldots + w_n x_n$$

$$\hat{y} = activation(z) \quad \begin{cases} if \;\; z \geq 0 \;\; , \;\; \hat{y} = 1 \\ if \;\; z < 0 \;\; , \;\; \hat{y} = 0 \end{cases}$$

$$Error = \Delta y = y - \hat{y}$$

Soft Computing 10

پرسپترون

- Activation function

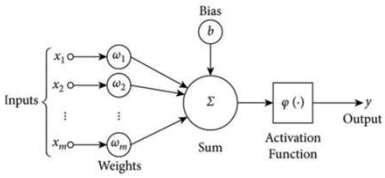

$$z = w_0 x_0 + w_1 x_1 + w_2 x_2 + \ldots + w_n x_n$$

$$\begin{cases} if\ z \geq 0\ , & \hat{y} = 1 \\ if\ z < 0\ , & \hat{y} = 0 \end{cases}$$

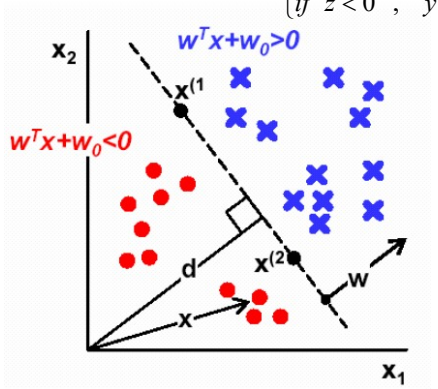

$$w_i + \eta . \Delta y . x_i \rightarrow w_i$$

x_i Input feature value
w_i Activation function
Δy Error
η Learning rate

Soft Computing 11

مثال پرسپترون: Logical AND

	x1	x2	T
P1 =	0	1	0
P2 =	1	1	1
Pn =	...	...	...

P2 الگویی است که باید پرسپترون یاد بگیرد:
یعنی، اگر هر دو ورودی ۱ هستند، خروجی با ید ۱ باشد

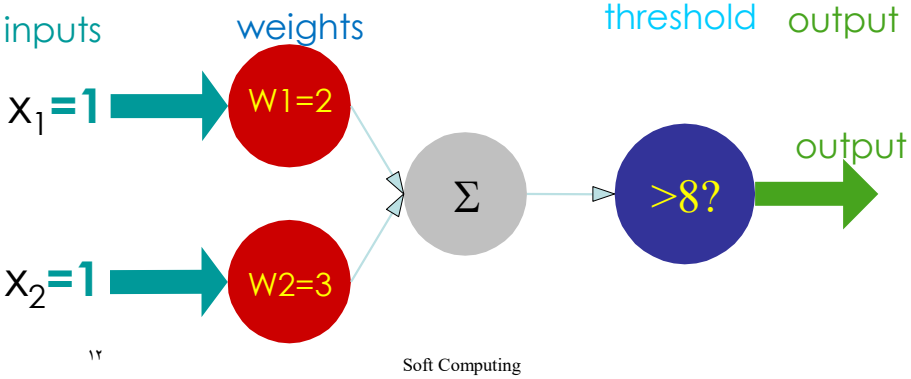

۱۲ Soft Computing

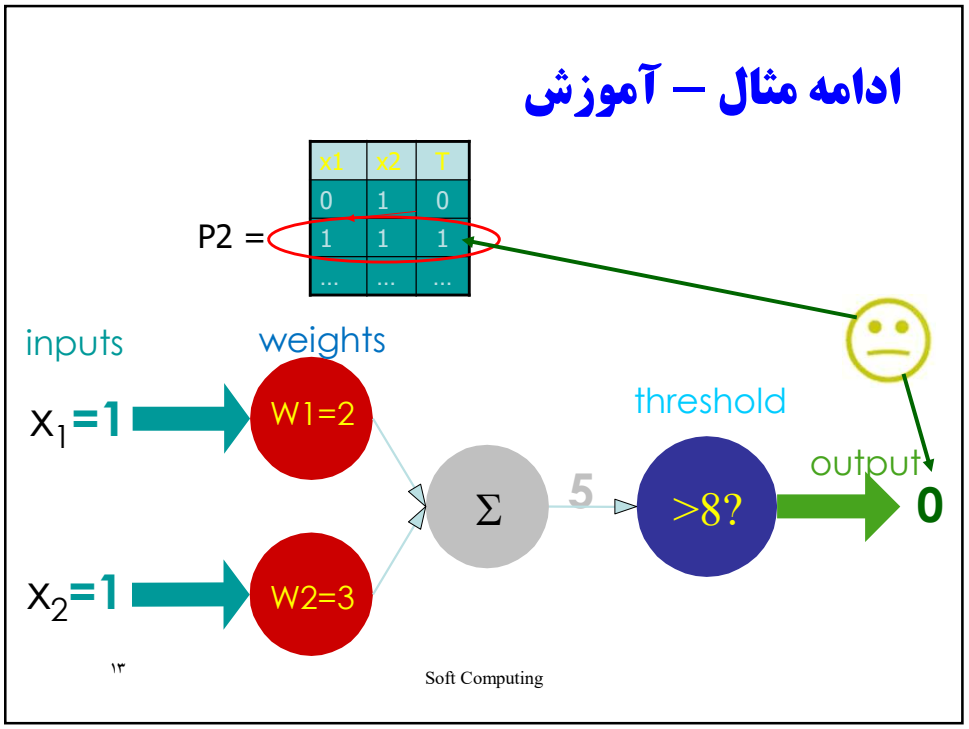

Linear Separability

•Examples (two dimensions):

OR function

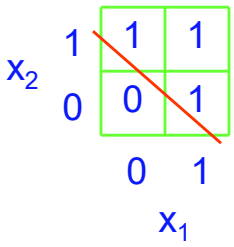

linearly separable

AND function

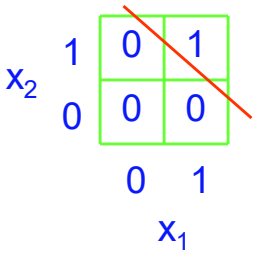

linearly separable

This means that a single threshold neuron can realize the OR and AND function.

Soft Computing

ادامه مثال – آموزش

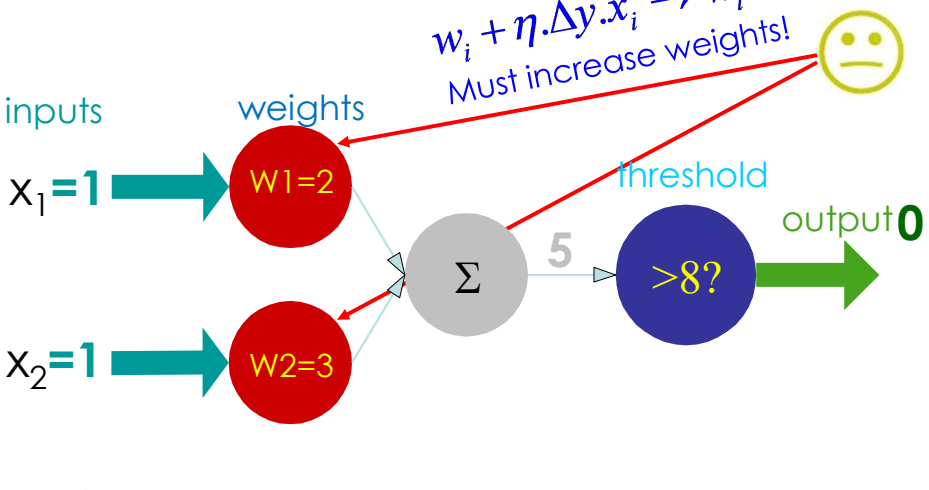

۱۵

Soft Computing

مثال پرسپترون: Logical OR

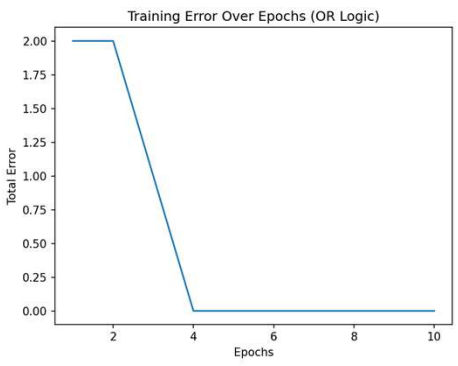

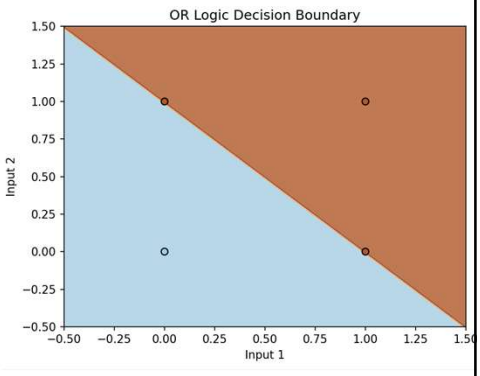

Soft Computing 16

مثال پرسپترون: Logical AND

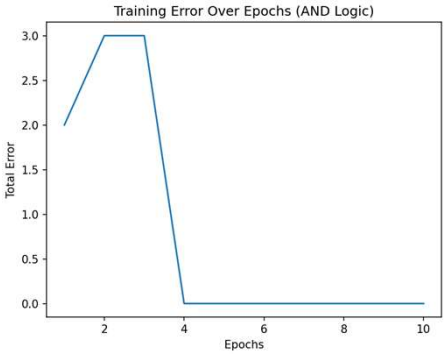

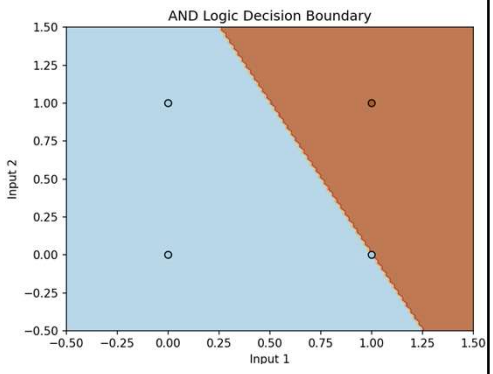

Soft Computing 17

Linear Inseparable

•Examples (two dimensions):

XOR function

x_2			
1	1	0	
0	0	1	
	0	1	x_1

linearly inseparable

XNOR function

x_2			
1	0	1	
0	1	0	
	0	1	x_1

linearly inseparable

This means that a single threshold neuron cannot realize the XOR and XNOR function.

Soft Computing

شبکه های پرسپترون چند لایه یا MLP

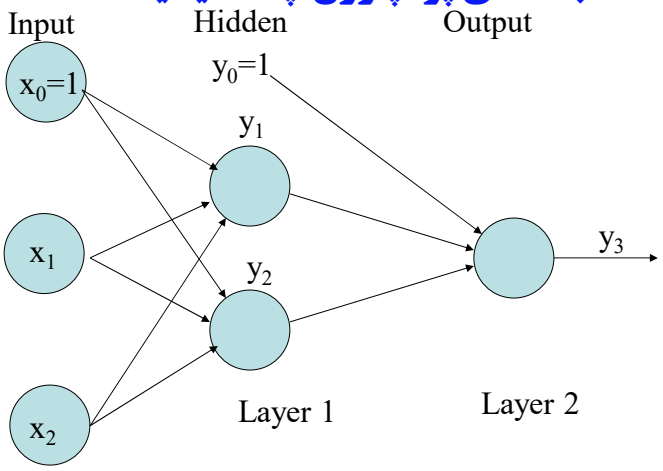

عملکرد پرسپترون چند لایه یا MLP

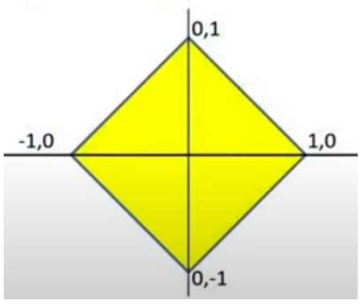

مثال:
چگونه می توان با پرسپترون نقاط داخل مربع را از سایر نقاط جدا کرد

حل:
به دلیل غیرخطی بودن کلاس وسط مربع با یک پرسپترون نمی‌توان طبقه‌بندی انجام داد

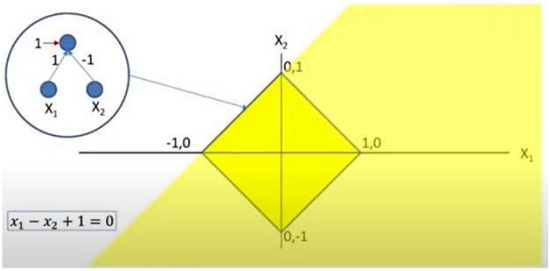

طبقه بندی با یک پرسپترون فقط خطی است

عملکرد پرسپترون چند لایه یا MLP

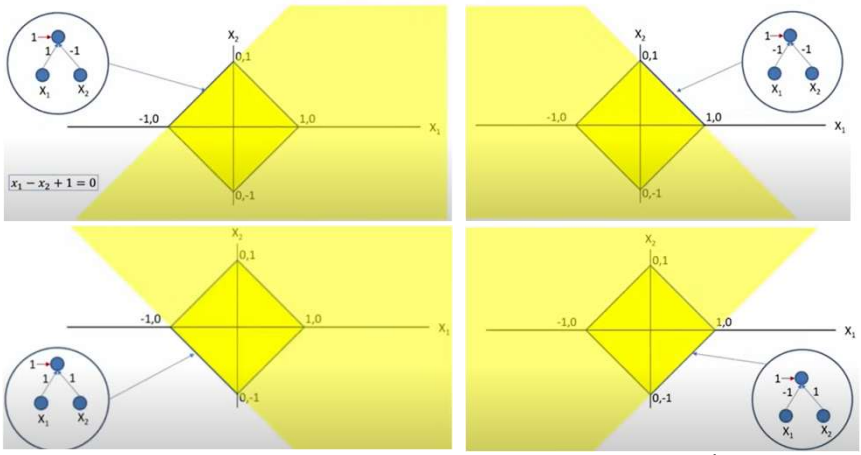

چهار طبقه بندی با یک پرسپترون می توان جواب مساله باشد

عملکرد پرسپترون چند لایه یا MLP

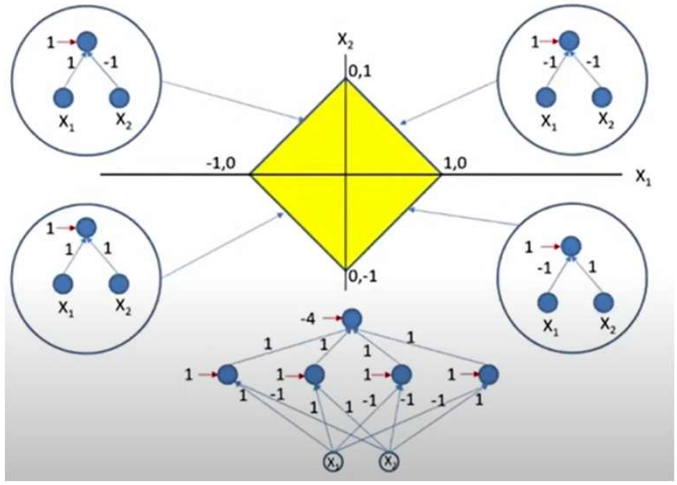

مثال پرسپترون چندلایه: Logical XOR

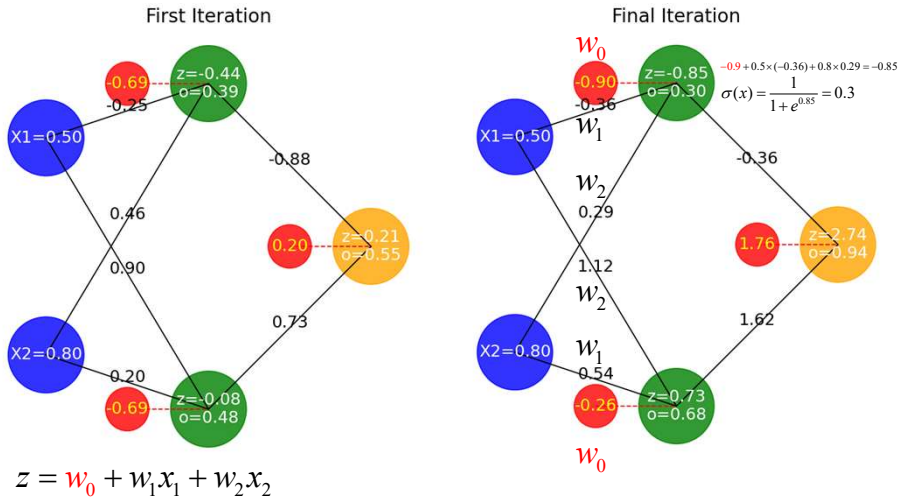

$$z = w_0 + w_1 x_1 + w_2 x_2$$

$$\sigma(x) = \frac{1}{1+e^{-x}}$$

مثال پرسپترون چندلایه: Logical XOR

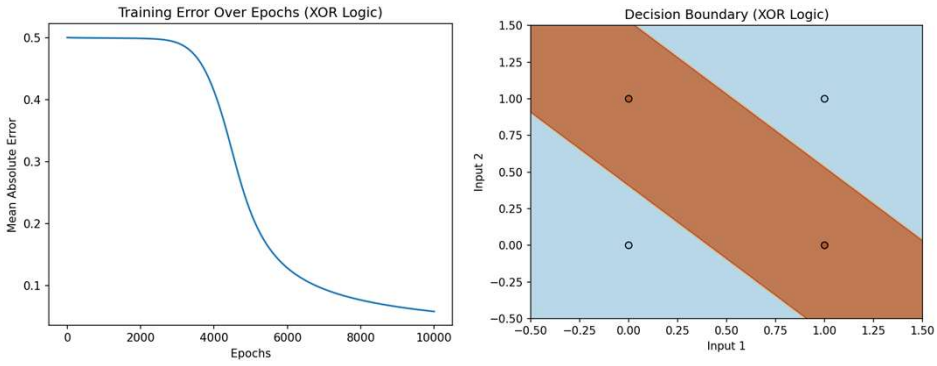

از روشهای مختلف از جمله گرادیان کاهشی برای تصحیح ضرایب وزنه استفاده می‌شود

مثال پرسپترون چندلایه : Logical XNOR

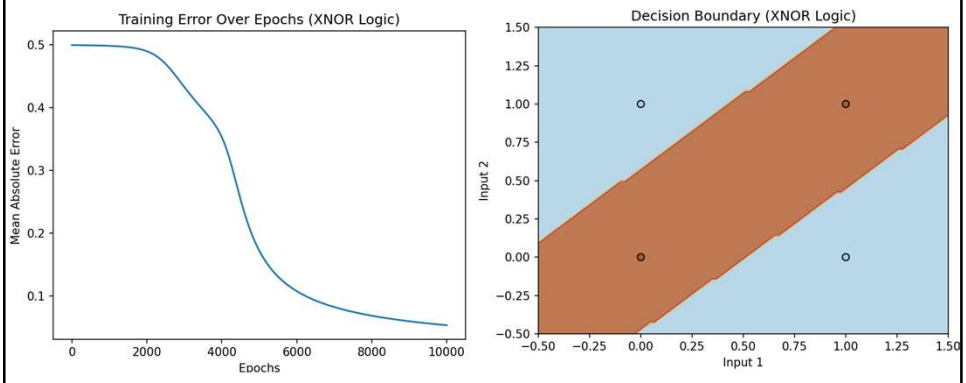

پرسپترون چند لایه، شبکه عصبی یا شبکه ژرف نیز نامیده می شود

شبکه عصبی – ویژگی های تابع فعال سازی

- **ویژگی‌های مورد نیاز**
  - **پیوسته**
  - **مشتق‌پذیر**
    - دارا بودن کارایی محاسباتی (به راحتی قابل محاسبه باشد)
    - مشتق تابع را بتوان برحسب مقدار خود تابع نوشت
  - **به صورت یکنوا غیرنزولی**
  - **قابلیت اشباع (Saturate)**
    - به صورت مجانبی به مقادیر بیشینه و کمینه خود نزدیک شود
- **سیگموید دودویی**

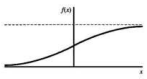

$$f_1(x) = \frac{1}{1+\exp(-x)}$$

$$f_1'(x) = f_1(x)[1 - f_1(x)]$$

- **سیگموید دوقطبی**
  - شباهت به تانژانت هیپربولیک

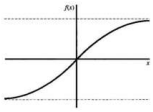

$$f_2(x) = \frac{2}{1+\exp(-x)} - 1$$

$$f_2'(x) = f_1(x) = \frac{1}{1+\exp(-x)}$$

با کشف الگوریتم پس-انتشار توسط رملهات، هینتن و ویلیامز در سال ۱۹۸۶ مطالعات جدید بر روی شبکه‌های عصبی مجددا شروع شد. اهمیت ویژه این الگوریتم این بود که شبکه‌های عصبی چند لایه توسط آن می‌توانستند آموزش داده شوند.

Comparison of Activation Functions

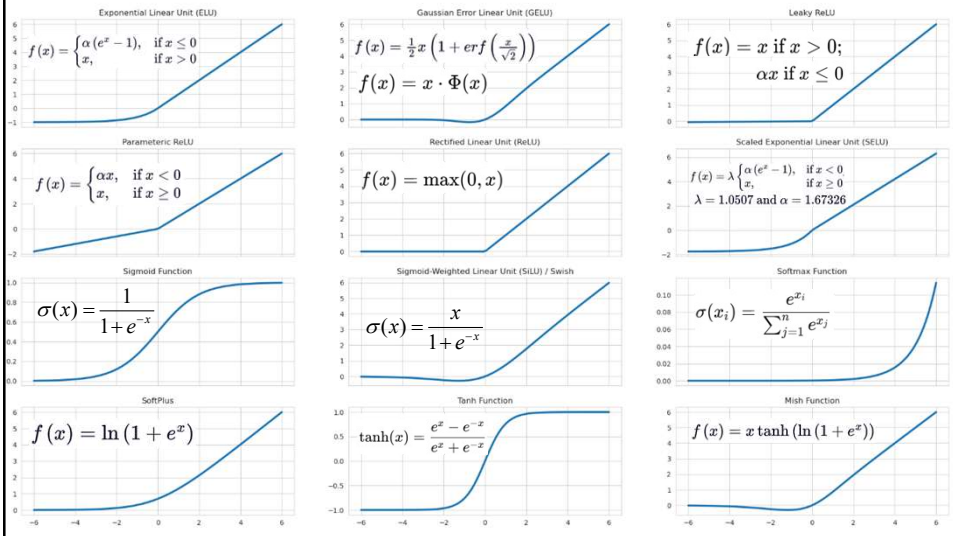

Comparison of Activation Functions

Activation Function		Range	Use Case	Advantages	Limitations
$\sigma(x) = \frac{1}{1+e^{-x}}$	Sigmoid	(0, 1)	Binary classification	Smooth, probabilistic output	Vanishing gradient, not zero-centered
$\tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}$	Tanh	(-1, 1)	Hidden layers	Zero-centered output	Vanishing gradient
$f(x) = \max(0, x)$	ReLU (Rectified Linear Unit)	[0, ∞)	Hidden layers	Efficient, avoids vanishing gradient	Dying neurons
$f(x) = x \text{ if } x > 0;$ $\alpha x \text{ if } x \le 0$	Leaky ReLU	(-∞, ∞)	Hidden layers	Avoids dying neurons	Arbitrary slope choice
$\sigma(x_i) = \frac{e^{x_i}}{\sum_{j=1}^{n} e^{x_j}}$	Softmax	(0, 1)	Output for multi-class problems	Probabilistic interpretation	Expensive for large datasets
$f(x) = x \cdot \sigma(x)$	Swish	(-∞, ∞)	Deep networks	Smooth and flexible	Slightly more computationally intensive
$f(x) = x \cdot \Phi(x)$	GELU	(-∞, ∞)	Transformer-based architectures	Smooth and efficient	Relatively new, computationally expensive

شبکه عصبی مصنوعی

افزایش تعداد لایه‌های برای پردازش مسایل پیچیده‌تر

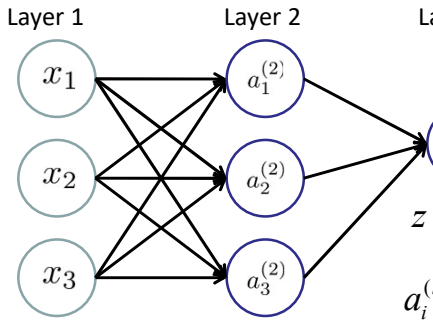

$$z = w_0 x_0 + w_1 x_1 + w_2 x_2 + \ldots + w_n x_n$$

$$a_i^{(l+1)}(x) = b_i^{(l)} + \sum_j w_{ji}^{(l)} a_i^{(l)}$$

$a_i^{(l+1)}$ activation of unit i in layer $l+1$

$w_{ji}^{(l)}$ Weight of unit i in layer $l+1$ receiving from unit j in layer l which control function mapping from layer l to layer $l+1$

شبکه عصبی مصنوعی

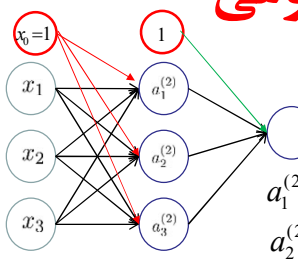

$$a_1^{(2)}(x) = g(b_1^{(1)} x_0^{(1)} + w_{11}^{(1)} x_1^{(1)} + w_{21}^{(1)} x_2^{(1)} + w_{31}^{(1)} x_3^{(1)})$$

$$a_2^{(2)}(x) = g(b_2^{(1)} x_0^{(1)} + w_{12}^{(1)} x_1^{(1)} + w_{22}^{(1)} x_2^{(1)} + w_{32}^{(1)} x_3^{(1)})$$

$$a_3^{(2)}(x) = g(b_3^{(1)} x_0^{(1)} + w_{13}^{(1)} x_1^{(1)} + w_{23}^{(1)} x_2^{(1)} + w_{33}^{(1)} x_3^{(1)})$$

$$h_w(x) = a_1^{(3)}(x) = g(b_1^{(2)} a_0^{(2)} + w_{11}^{(2)} a_1^{(2)} + w_{21}^{(2)} a_2^{(2)} + w_{31}^{(2)} a_3^{(2)})$$

Learnable parameter for l layer

$$\sum_1^{l-1} (N_L + 1)(N_{L+1}) = (N_1 + 1)N_2 + (N_2 + 1)N_1 \ldots (N_{L-1} + 1)N_l$$

N_l Number of neuron in l layer

شبکه عصبی مصنوعی

pip install tensorflow

pip install intel-tensorflow Use **Intel-optimized TensorFlow**

```
import os
import numpy as np
import random
import matplotlib.pyplot as plt
from sklearn.datasets import make_classification
from sklearn.model_selection import train_test_split
from sklearn.preprocessing import StandardScaler
from sklearn.metrics import accuracy_score, ConfusionMatrixDisplay

# Optional: Disable oneDNN custom operations to avoid floating-point warnings
os.environ["TF_ENABLE_ONEDNN_OPTS"] = "0"
os.environ['TF_CPP_MIN_LOG_LEVEL'] = '2' #Suppress TensorFlow INFO and WARNING logs

import tensorflow as tf
from tensorflow.keras.models import Sequential
from tensorflow.keras.layers import Dense, Input

# Set random seeds for reproducibility
np.random.seed(42)
tf.random.set_seed(42)
random.seed(42)
```

13 ANN.py

شبکه عصبی مصنوعی

```
# Generate a 2D dataset for visualization
X, y = make_classification(
    n_samples=200, n_features=2, n_informative=2, n_redundant=0,
n_clusters_per_class=1, random_state=42
)

# Standardize the dataset
scaler = StandardScaler()
X = scaler.fit_transform(X)

# Split the dataset into training and testing sets
X_train, X_test, y_train, y_test = train_test_split(X, y,
test_size=0.3, random_state=42)

# Build the ANN model
def build_model(input_dim, output_dim):
    """
    Build a simple feedforward ANN model with two hidden layers.
    """
    model = Sequential([
        Input(shape=(input_dim,)),  # Explicit Input layer
        Dense(4, activation='relu'),  # 4 neuron First hidden layer
        Dense(2, activation='relu'),  # 2 neuron Second hidden layer

        Dense(output_dim, activation='sigmoid')  # Output layer for
binary classification
    ])
    return model
```

شبکه عصبی مصنوعی

```
# Train, evaluate, and plot ANN
def train_evaluate_ann(epochs=50, batch_size=8):
    """
    Train the ANN, evaluate on test data, and visualize results.
    """
    print("Training Artificial Neural Network...")

    # Build and compile the model
    model = build_model(input_dim=2, output_dim=1)
    model.compile(optimizer='adam', loss='binary_crossentropy',
metrics=['accuracy'])

    # Train the model
    history = model.fit(X_train, y_train, epochs=epochs,
batch_size=batch_size, verbose=0)

    # Evaluate on test set
    y_pred = (model.predict(X_test) > 0.5).astype(int)
    accuracy = accuracy_score(y_test, y_pred)
    print(f"Test Accuracy: {accuracy:.2f}")

    # Plot decision boundary
    plot_ann_with_boundary(X_train, y_train, model, accuracy)

# Run the ANN training and visualization
if __name__ == "__main__":
    try:
        train_evaluate_ann(epochs=50, batch_size=8)
    except Exception as e:
        print(f"An error occurred: {e}")
# Predict a new example
    predict_new_example(model, scaler, target_names)
```


مثال

حل مساله به روش شبکه عصبی برای مثال دسته بندی در قسمت SVM

- اجرای اول

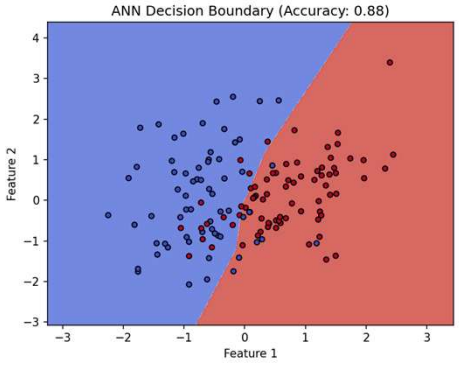

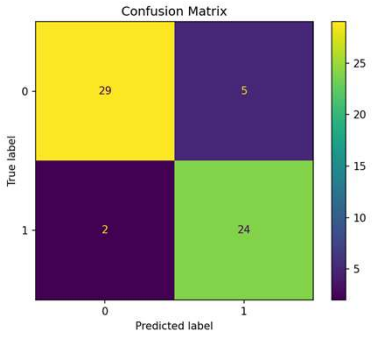


```
model = Sequential([
    Input(shape=(input_dim,)),  # Explicit Input layer
    Dense(4, activation='relu'),  # 4 neuron First hidden layer
    Dense(2, activation='relu'),  # 2 neuron Second hidden layer
    Dense(output_dim, activation='sigmoid')  # Output layer for binary classification
```

مثال

حل مساله به روش شبکه عصبی برای مثال دسته بندی در قسمت SVM

- اجرای اول

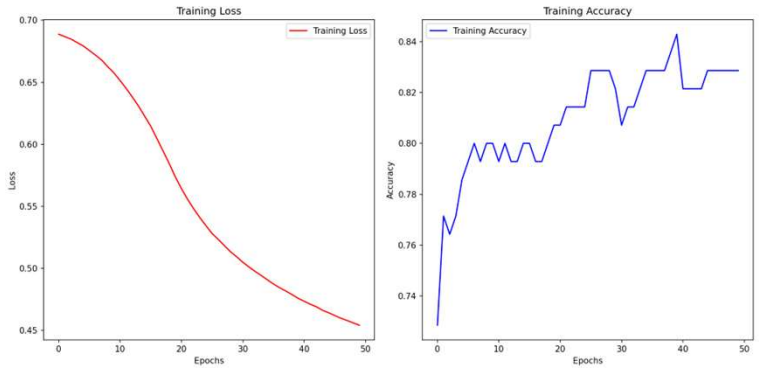

مثال

حل مساله به روش شبکه عصبی برای مثال دسته بندی در قسمت SVM

- اجرای دوم - حساسیت به شرایط اولیه

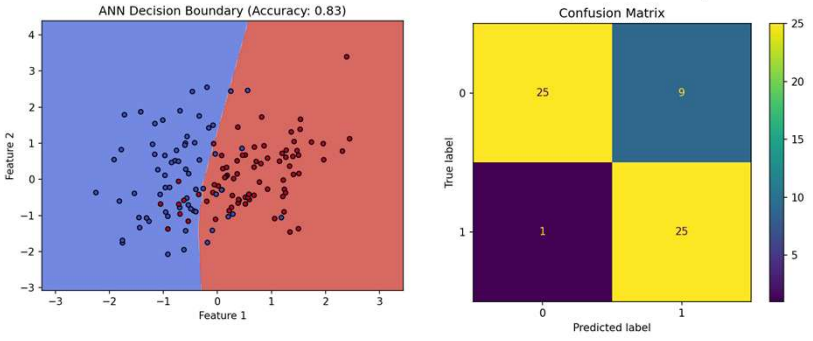


```
model = Sequential([
    Input(shape=(input_dim,)),  # Explicit Input layer
    Dense(4, activation='relu'),  # 4 neuron First hidden layer
    Dense(2, activation='relu'),  # 2 neuron Second hidden layer
    Dense(output_dim, activation='sigmoid')  # Output layer for binary classification
```

مثال

حل مساله به روش شبکه عصبی برای مثال دسته بندی در قسمت SVM

- اجرای دوم

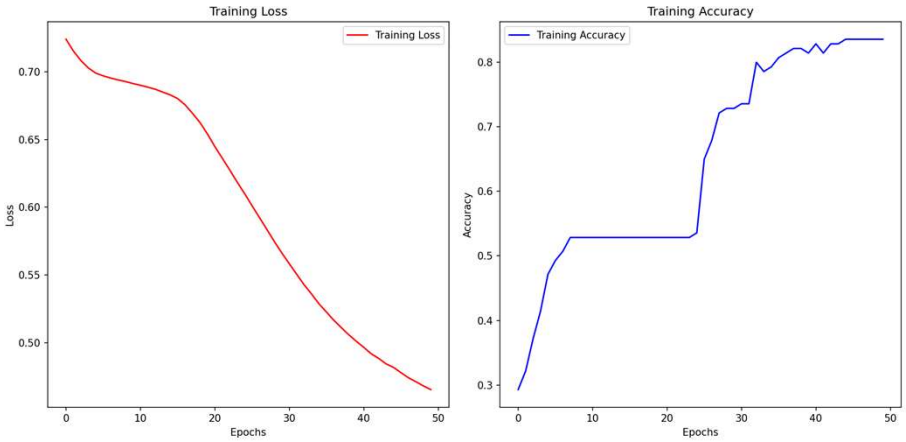

Soft Computing 37

مثال

حل مساله به روش شبکه عصبی برای مثال دسته بندی در قسمت SVM

- اجرای سوم – شرایط اولیه یکسان

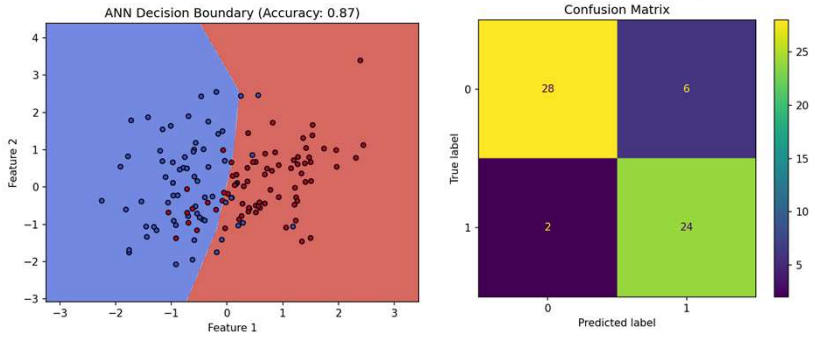

Set Random Seeds:
•Fixing the random seed ensures reproducibility across runs.

```
np.random.seed(42)
tf.random.set_seed(42)
random.seed(42)
```

13 ANN replace SVM.py

Soft Computing 38

مثال

حل مساله به روش شبکه عصبی برای مثال دسته بندی در قسمت SVM

- اجرای سوم

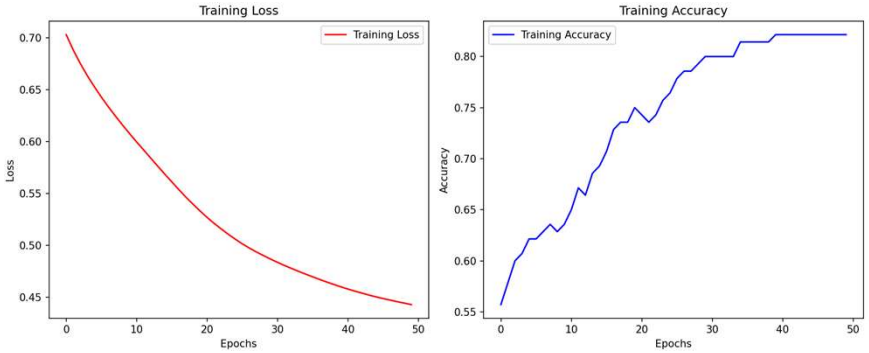

Soft Computing 39

مثال

حل مساله گلهای زنبق

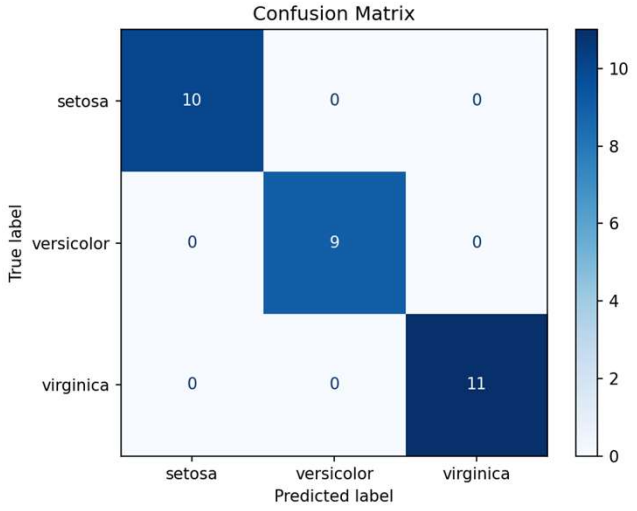

Soft Computing 40

مثال

حل مساله گلهای زنبق

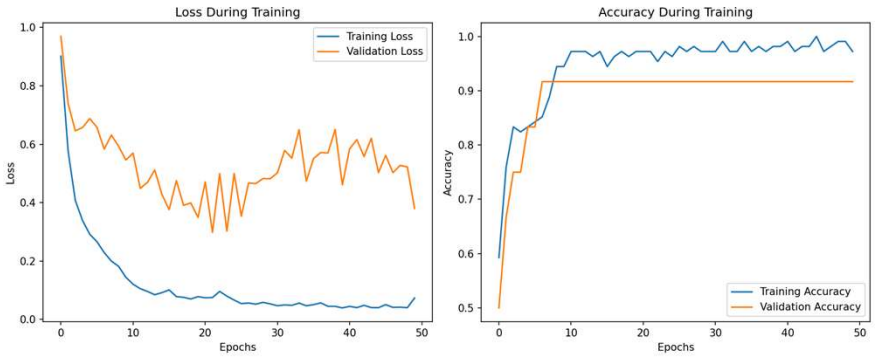

New Example Features: [5.9 3. 5.1 1.8]
Predicted Class: virginica

معماری شبکه هوش مصنوعی

•First hidden layer, the number of neurons is often: $n > n_{input\ features} + n_{output\ targets}$

•Subsequent layers, try reducing the number of neurons progressively (e.g., 64 → 32 → 16).

Example

1. Binary Classification
•Input Features: 10
•Output Classes: 2

•Suggested Architecture:
- •Input Layer: 10 neurons (input size).
- •Hidden Layer 1: 16 neurons (capture interactions).
- •Hidden Layer 2: 8 neurons (reduce complexity).
- •Output Layer: 2 neuron (sigmoid activation).

2. Multiclass Classification
•Input Features: 20
•Output Classes: 5

•Suggested Architecture:
- •Input Layer: 20 neurons.
- •Hidden Layer 1: 32 neurons (capture higher-level features).
- •Hidden Layer 2: 16 neurons.
- •Output Layer: 5 neurons (softmax activation).

3. Regression
•Input Features: 5
•Output: Continuous value

•Suggested Architecture:
- •Input Layer: 5 neurons.
- •Hidden Layer 1: 10 neurons (nonlinear mapping).
- •Output Layer: 1 neuron (linear activation).

Use learning curves to analyze underfitting (high training loss) or overfitting (low training loss, high validation loss)

شبکه عصبی مصنوعی

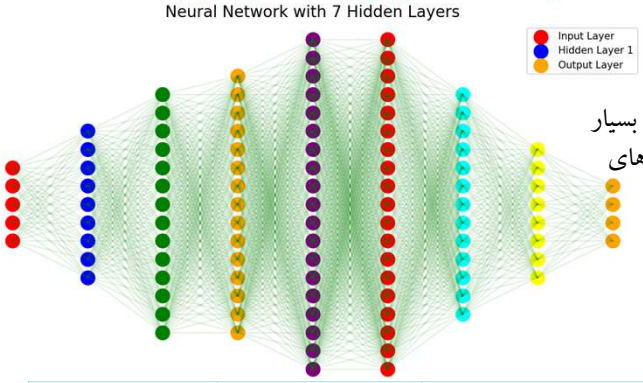

شبکه عصبی می‌تواند بسیار پیچیده شده و پارامترهای زیادی داشته باشد

Feature	GPT-3	GPT-4 (Speculated)
Number of Layers	96	Likely >120
Parameters	175 billion	500 billion to 1 trillion
Context Length	2,048 to 4,096 tokens	Up to 32,768 tokens (or more)
Training Data	570 GB of filtered text	Larger and more diverse dataset
Vector Dimension	12,288	Likely 16,384 or more

43

Soft Computing

عنوان پروژه: پیش‌بینی مقاومت بتن با استفاده از **شبکه عصبی چندلایه (MLP)** در PyTorch

پروژه پایانی: یک برنامه به زبان پایتون بنویسید که یک فایل داده را خوانده و به روش شبکه عصبی مصنوعی موارد زیر را انجام دهد.

۱- تعریف یک مدل MLP
۲- تعیین و تنظیم تعداد لایه‌های پنهان و نرونها
۳- تعیین توابع فعالسازی مناسب
۴- پیش بینی مناسب مقاومت فشاری بتن
۵- تعیین میزان خطا

Data set: "Concrete Compressive Strength"
Input.: 8 Features
Output: Concrete strength
Sample No.: 1030

PyTorch : کتابخانه متن‌باز برای یادگیری عمیق که در سال ۲۰۱۶ توسط فیسبوک توسعه داده شده است. علاوه بر سادگی و پشتیبانی قوی در انجمن‌ها و شبکه‌های اجتماعی دارای ویژگیهای زیر است:

- کتابخانه‌های غنی. مثل torchvision (کار با تصاویر)، torchtext (پردازش متن) و torchaudio (کار با صدا).
- محاسبات گراف‌های پویا (قابلیت تعریف و تغییر مدل و گراف محاسباتی حین اجرا)
- سازگاری با سایر کتابخانه ها نظیر Numpy و Scikit-Learn
- پشتیبانی از کارت‌های گرافیک

Soft Computing 44

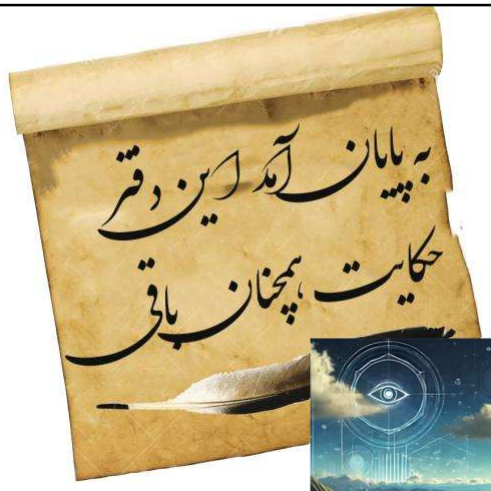

به دنبال آرزوهایم خواهم رفت

عهد بسته‌ام قبل از مرگ نمیرم

Soft Computing 45